



# **Universidad de Cuenca**

Facultad de Ingeniería

Maestría en Vialidad y Transporte

Título:

**Análisis de Viajes con la Aplicación de Teléfonos Inteligentes**

Proyecto de Graduación previo a la obtención del Grado de Máster en Ingeniería en  
Vialidad y Transporte

Autor:

**Juan Marcelo Avilés Ordóñez**

**C.I. 0103872503**

Director:

**Blgo. Daniel Augusto Orellana Vintimilla PhD.**

**C.I. 0102367554**

**Cuenca, Julio / 2016**



## Contenido

1	Introducción.....	7
2	Metodología .....	8
2.1	Desarrollo de aplicación móvil.....	8
2.2	Implementación piloto .....	9
2.3	Análisis de datos por post–proceso .....	9
2.3.1	Matrices de origen destino:.....	10
2.3.2	Matrices de tiempos de viajes:.....	11
2.3.3	Modos de transporte:.....	11
2.3.4	Identificación de rutas más frecuentes: .....	12
2.4	Validación.....	13
3	Resultados y Discusión .....	13
3.1	Detección de POIs .....	14
3.2	Matriz origen - destino.....	15
3.3	Matrices de tiempo de viajes .....	19
3.4	Modos de Transporte .....	21
3.5	Identificación de rutas .....	22
4	Conclusión .....	25
5	Referencias .....	27



Universidad de Cuenca  
Clausula de derechos de autor

---

*Juan Marcelo Aviles Ordóñez*, autor/a de la tesis "Análisis de Viajes con la Aplicación de Teléfonos Inteligentes", reconozco y acepto el derecho de la Universidad de Cuenca, en base al Art. 5 literal c) de su Reglamento de Propiedad Intelectual, de publicar este trabajo por cualquier medio conocido o por conocer, al ser este requisito para la obtención de mi título de Magister en Ingeniería Vial y de Transportes. El uso que la Universidad de Cuenca hiciere de este trabajo, no implicará afección alguna de mis derechos morales o patrimoniales como autor/a

Cuenca, a 30 de Julio de 2016

---

Juan Marcelo Avilés Ordóñez

C.I.: 010387250-3



Universidad de Cuenca  
Clausula de propiedad intelectual

---

Juan Marcelo Avilés Ordóñez, autor/a de la tesis "Análisis de Viajes con la Aplicación de Teléfonos Inteligentes", certifico que todas las ideas, opiniones y contenidos expuestos en la presente investigación son de exclusiva responsabilidad de su autor/a.

Cuenca, a 30 de Julio de 2016

---

Juan Marcelo Avilés Ordóñez

C.I: 010387250-3



# Análisis de Viajes con la Aplicación de Teléfonos Inteligentes

Juan Avilés<sup>1</sup>, Daniel Orellana<sup>2</sup>

<sup>1</sup> Facultad de Ingeniería, Universidad de Cuenca, [juan.aviles@ucuenca.edu.ec](mailto:juan.aviles@ucuenca.edu.ec).

<sup>2</sup> LlactaLab – Ciudades Sustentables, Facultad de Ciencias Agropecuarias, Universidad de Cuenca, [daniel.orellana@ucuenca.edu.ec](mailto:daniel.orellana@ucuenca.edu.ec)

Cuenca - Ecuador.

**Resumen:** Se han desarrollado varios modelos prometedores para la captura digital de datos de movilidad, que pueden ser aplicados en la planificación urbana, de transporte y de ordenamiento territorial. Por ello el objetivo de este trabajo es desarrollar una metodología que recolecte información de movilidad con la cual se generen matrices Origen-Destino (OD) y de tiempos de viajes, además que identifique puntos de interés, modos y rutas frecuentes de viaje mediante el desarrollo e implementación de una aplicación para dispositivos móviles Android.

**Metodología:** Se produjo una aplicación para dispositivos móviles con sistema operativo Android, en base a modelos existentes. Esta aplicación obtuvo datos de movilidad a partir de los sensores de localización incorporados en los móviles (GPS), para su posterior migración a una base de datos en la nube y consiguiente post proceso con herramientas de análisis como KNIME, Python y QuantumGis. La aplicación fue probada por 68 estudiantes voluntarios de la Universidad de Cuenca, durante 14 días del mes de enero de 2016. **Resultados:** Con la información completa de 44 participantes se obtuvieron matrices OD y de tiempos de viajes para diferentes períodos del día, las cuales permitieron identificar variaciones de interacción entre zonas, variaciones de número y tiempo de viajes. Fueron reconocidos también modos de transporte como caminata, bicicleta y motorizados para una sub muestra (n=6). Se detectaron los POIs Residencia (91%), Trabajo/Estudio (74%) y puntos intermedios (20% del total de POIs) y se logró observar comportamientos de movilidad atípico. Finalmente se compararon las rutas más frecuentadas por los usuarios con las rutas óptimas teóricas calculadas, encontrando que el 63.6% de los usuarios coincidían con el recorrido de estas últimas. **Conclusiones:** El método planteado presenta coherencia con trabajos previos, mostrando niveles de confianza equiparables. El mayor reto es la implementación masiva del modelo creado para la recolección de datos útiles para planes de movilidad.

**Palabras Claves:** Teléfonos inteligentes, movilidad, matriz OD, tiempo de viaje, modalidad, transporte, tráfico.



**Abstract:** Previous research has developed several promising models for digital data capture mobility, which can be applied in urban planning, transportation and land use planning models. Therefore the aim of this work is to develop a methodology to produce information mobility on Origin-Destination (OD) and travel time matrices, identification of travel modes, points of interest (POIs) and frequent routes through the development and implementation of an application for Android mobile devices.

**Methodology:** There was an application for mobile devices with Android operating system, based on existing models. This application obtained mobility data from sensors embedded in mobile location (GPS). Data was subsequent migration to a cloud database. Post process analysis was conducted with tools such as KNIME, Python and QuantumGIS. The application was tested by 68 students volunteer from the University of Cuenca, for 14 days in January 2016. **Results:** We obtained data from 44 volunteers for create OD matrices and travel times matrices for different periods of the day. These matrices helped to identify variations of interaction between areas, number and time of travel. They were identified modes of transport such as cycling and motorized. POIs House (91%), Work (74%) and intermediate stops (20% of total POIs) were detected. A mobility atypical behaviors were observed. Finally the compared of routes frequented vs theoretical optimal routes finding that 63.6% of users agreed with total of travel of the latter. **Conclusions:** The proposed method of analysis and recollection of data presents consistent with previous studies showing comparable levels of confidence. The biggest challenge is the massive deployment model for the collection of useful data mobility plans.

**Keywords:** Smartphone, mobility, OD matrix, travel time, modality, transport, traffic.



## 1 Introducción

La mayoría de modelos clásicos de demanda de tráfico se basan en el modelo 4 etapas desarrollado a mediados del siglo XX. Este modelo incluye: 1) la *generación de viajes*, basado en datos socioeconómicos; 2) la *distribución de viajes*, basados en modelos gravitatorios utilizando posibles atractores y generadores; 3) la *división de modos de transporte*; y 4) la asignación de rutas en base a matrices de impedancia que identifican y distribuyen a los usuarios en diferentes rutas y modos de transporte para llegar a sus destinos [1]. Aunque este modelo no ha estado exento de críticas, puede ser útil en la planificación y el diseño de sistemas de tránsito, si modifica e incorpora las diversas variables que afectan sus resultados (ej.: existencia previa de una red de transporte, políticas de integración, adaptación al área/grupo de estudio, entre otras) [2, 3]. Independientemente del enfoque aplicado, los modelos de transporte son de gran utilidad para ingenieros de tránsito, planificadores, políticos, desarrolladores y agencias de transporte, ya que les permitirá evaluar la infraestructura existente (camino, ciclo vías, corredores urbanos y rurales), la funcionalidad de los sistemas de transporte y planificar escenarios futuros. Una de las mayores limitaciones para la implementación de estos modelos es la disponibilidad de datos de movilidad.

La producción de información de movilidad se ha basado tradicionalmente en la recolección de datos mediante encuestas en hogares [1]. La utilización de este método implica altos costos en términos de logística y tiempo debido a la necesidad de cumplir con una extensa muestra que alcance niveles de confianza aceptables (85% al 95%) [1, 4]. Sin embargo, en la actualidad existen diversas técnicas de recolección automática de información de movilidad las cuales son de fácil implementación [5, 6]. Una de estas técnicas es la adquisición de bases de datos a nivel global mediante proveedores de información de movilidad (ej.: operadoras de telefonía móvil, librerías de redes sociales basada en la localización) [5]. Empero la ejecución de esta opción es menos tentadora en países en los que existen dificultades para su implementación (debido a la escasez de información o dificultades de acercamiento con los proveedores). Otras técnicas de recolección de información de movilidad están basadas en el uso de dispositivos de posicionamiento GPS y otros sensores incorporados en los teléfonos móviles inteligentes [7, 8]. La información de movilidad recolectada de esta manera puede ser de gran utilidad ya que puede generar datos útiles para el modelo de 4 etapas [8, 9]. Más aún, este tipo de técnicas permiten producir valiosa información sobre viajes cortos e intermedios, rutas más utilizadas, tiempos exactos, modalidades de transporte, entre otros, que sería extremadamente difícil o imposible utilizando las técnicas tradicionales [10].

No obstante, las aplicaciones existentes para dispositivos móviles, tienen algunas limitaciones, tales como la dificultad para obtener los datos originales para análisis, problemas con el excesivo consumo de batería, requerimiento de conectividad permanente a redes de datos para la transferencia, entre otras. Estas limitaciones dificultan la adopción de técnicas de recolección de datos de movilidad basadas en dispositivos móviles, tanto por parte de los usuarios como de los investigadores. De



hecho, en el caso de Ecuador, no se conoce que se haya implementado este tipo de técnicas.

Por lo tanto, el objetivo de este estudio es implementar un método de recolección y análisis de datos de movilidad basado en teléfonos inteligentes Android que genere información sobre: i) matrices de Orígenes-Destino (OD), ii) matrices de tiempos de viajes, iii) modos de transporte, iv) puntos de interés, y v) identificación de rutas. Esta aplicación debe cumplir con tres requisitos básicos: 1) Producir datos de localización espacio-temporal del usuario de forma automática y enviarlos a un servidor central, 2) Limitar en lo posible el consumo de batería del dispositivo, y 3) No depender de una conexión permanente a una red de datos para la sincronización con el servidor.

En este documento se presenta el proceso de desarrollo de la aplicación de recolección de datos y una prueba piloto de implementación, así como los métodos utilizados para el análisis de datos. Se presenta también los resultados obtenidos del análisis y su relación con el Modelo de 4 Etapas y finalmente algunas conclusiones y los pasos futuros de la investigación.

## 2 Metodología

La metodología para de captura digital de datos de movilidad se estructuró en 4 fases: 1) Desarrollo de la aplicación móvil, 2) Implementación piloto, 3) Análisis de datos por post-proceso, y 4) Validación. A continuación se detallan cada una de estas fases.

### 2.1 Desarrollo de aplicación móvil

Se desarrolló una aplicación de recolección de datos de movilidad para dispositivos móviles con sistema operativo Android (versiones 3.0 a 5.0). Se seleccionó esta plataforma por ser la más popular entre los usuarios de teléfonos inteligentes [11], en la que las versiones mencionadas representaron entre el 65 al 75% del mercado a inicios de 2016 [12, 13]. La programación se realizó mediante código fuente Java, a través de la plataforma Eclipse. La aplicación fue generada con el objetivo de recolectar la ubicación reportada por el sensor de localización de posicionamiento global (GPS) incorporado en los móviles y su posterior almacenamiento en una base de datos en la memoria ROM del teléfono. La información almacenada se envió de forma diferida a una base de datos en un servidor central, para lo cual se requirió una acción de los usuarios. De esta manera, no se requirió una

conexión de datos permanente y fue posible ejecutarlo solamente cuando existía conectividad WiFi [14] (**Figura 1**).

La primera versión de la aplicación se diseñó para que detecte viajes o movimientos mediante un algoritmo interno, para lo cual la aplicación realizaba peticiones de ubicación al GPS del dispositivo de forma permanente durante las 24 horas del día. Esto permitió tener un algoritmo preciso, pero con un gran consumo de batería. Para superar esta dificultad se ensayó varios intervalos de tiempo de peticiones de ubicación, sin producir una mejora significativa.



Por lo tanto, se implementó un algoritmo adaptativo para la versión final, el cual utiliza diferentes señales de sensores para optimizar las solicitudes de ubicación al GPS. En primer lugar, el algoritmo evalúa las conexiones WiFi, interrumpiendo las peticiones de ubicación mientras se encuentre conectado a una misma red (se asume que el usuario mantiene su ubicación). Cuando se detecta una desconexión de la red WiFi, el algoritmo solicita la ubicación al GPS, y repite esta petición dependiendo de la velocidad promedio del movimiento, es decir a mayor velocidad, mayor número de peticiones [15].

El algoritmo incluye además un método para la detección de modalidad de transporte basado en datos del acelerómetro. El usuario tiene la opción de validar esta información al terminar cada día mediante un módulo de la aplicación. Estos datos son también transferidos al servidor para su análisis.

El algoritmo adaptativo mejoró sensiblemente el rendimiento de la batería, pero dificultó la detección de viajes en tiempo real en el dispositivo, por lo que dicha detección se realizó mediante un análisis por un post proceso utilizando KNIME, Python y QuantumGis (QGIS).




Figura 1. Esquema de Base de Datos

## 2.2 Implementación piloto

La aplicación fue desplegada en una implementación piloto con estudiantes voluntarios de la Universidad de Cuenca, quienes la utilizaron para recolectar datos de movilidad. Los voluntarios recibieron una capacitación sobre la utilización de la aplicación móvil y provistos del “Manual de instalación y utilización” (**ANEXO 1**). Los datos recolectados por la aplicación fueron agregados en un servidor y luego fueron depurados para el análisis, excluyendo a los usuarios con información nula o insuficiente (menor a 3 días).

## 2.3 Análisis de datos por post-proceso

La información generada y almacenada en la base de datos fue procesada en el programa KNIME [16]. Se utilizó el algoritmo de detección de clúster espacial DBSCAN (épsilon=0.0015, número mínimo de puntos=10) por su capacidad de minimizar los efectos de los errores [17] originados por la distorsión de la señal del GPS debido al efecto de rebote en edificaciones circundantes, la geometría de la constelación de satélites, las variaciones de precisión de los GPS de los equipos móviles, entre otros. El algoritmo analizó los datos diarios de cada usuario para



identificar clústeres espaciales que representaron lugares donde el usuario suspendió su movimiento. Estos clústeres fueron clasificados en función de su duración: Aquellos menores a 10 minutos fueron paradas involuntarias [15], y los restantes fueron Puntos de Interés (POIs). Finalmente, se analizó la hora de inicio y finalización y la duración de la estancia en cada POI para una segunda clasificación [15], como se describe a continuación:

- $POI_R$  (Lugar de residencia): POI identificado como el mayor tiempo de permanencia entre las 20h00 pm hasta las 5h00 am de los días analizados.
- $POI_T$  (Lugar de Trabajo/Estudio): POI identificado como el mayor tiempo de permanencia entre las 5h00 am hasta las 20h00 pm de los días analizados.
- $POI_I$  (Punto intermedio): POI identificado como una estancia  $\geq 10$  minutos en un lugar, siempre que este no haya sido determinado previamente como  $POI_R$  o  $POI_T$ .

Con la determinación de los POIs y conservando el lapso de tiempo durante el cual el usuario permanecía en la ubicación, se procedió a generar las matrices OD y de tiempos de viajes, además de la detección de modos de transporte, categorización de POIs e identificación de rutas frecuentes de viaje.

### 2.3.1 Matrices de origen destino:

Las matrices de Origen – Destino (OD) indican el número de viajes entre distintas zonas de la ciudad. En este caso, se utilizaron las unidades funcionales propuestas en el Plan de Movilidad de la ciudad de Cuenca [4].

A cada  $POI_{(R, T, I)}$  se le asignó las coordenadas del centroide de la unidad funcional en la cual se ubicaban geográficamente (Figura 2). A partir de ello se establecieron los viajes entre zonas, a partir de la secuencia espacio-temporal de los POIs, para así generar modelos de distribución de viajes. Estos modelos se obtuvieron contando el número de viajes entre zonas mediante código Python. Con los datos de distribución de viajes se generaron cuatro matrices de origen destino para cada día y para cuatro períodos de tiempo: A) 0h00 a 11h00am, B) 11h00 a 15h00, C) 15h00 a 0h00 y D) de 00h00 a 24h00. Esta división se efectuó para analizar la distribución de los viajes a lo largo del día hacia diferentes lugares de la ciudad en función de viajes pendulares ( $POI_R \rightarrow POI_T$ ,  $POI_T \rightarrow POI_R$ ) y viajes intermedios (ej.:  $POI_T \rightarrow POI_I \rightarrow POI_R$ ). Las interacciones entre zonas fueron denominadas como viajes interzonales, mientras que las interacciones dentro de una misma zona como intrazonales.



La matriz de tiempos de viajes indica la mediana de los tiempos de desplazamiento entre zonas de la ciudad. De forma similar a la matriz OD, se calcularon todos los desplazamientos entre zonas y se calculó la mediana del tiempo de viaje sin distinción entre las modalidades de transporte. Se optó por la mediana en lugar de la media debido a que este estadístico es más resistente a los valores extremos usualmente encontrados en los tiempos de desplazamiento que pueden provenir de errores debido a las deficiencias de la precisión del GPS o por suspensión de los equipos móviles debido a batería agotada.

Los modos de transporte fueron clasificados en cuatro categorías: *motorizado*, *bicicleta*, *caminata* y *suspendido* (este último representa la ausencia de movimiento de translación [18]) fueron determinados en base a un árbol de decisión probado previamente en varias personas de distinto sexo y diferentes edades [15]. Para cada viaje registrado se obtuvo el promedio de los valores de velocidad y aceleración, con estos promedios se determinó el modo de viaje mediante un árbol de decisión (**Figura 3**). La velocidad de movimiento fue categorizada de la siguiente manera: alta (mayor a 30km/h), media (10 a 30 km/h), baja (menor a 10km/h) y suspendido (menor a 0.3 km/h). Mientras que la aceleración se determinó con un umbral de movimiento

previamente ensayado [15], sin embargo el mismo tuvo que ser ajustado (1.0 G menos) para obtener datos coherentes: alta ( $\geq 1.0G$ ) o baja ( $< 1.0G$ ). El modo fue clasificado como *motorizado* si el usuario registró una aceleración baja; o una aceleración alta y una velocidad alta; el modo *bicicleta* se identificó si existió una aceleración alta y una velocidad media; finalmente el modo *caminata* se determinó si la aceleración fue alta y la velocidad baja.




Figura 3. Flujograma: Árbol de decisión del modo de transporte

#### 2.3.4 Identificación de rutas más frecuentes:

Se identificaron las rutas más frecuentes (RMF) de cada usuario aplicando un algoritmo estimador de densidad kernel (radio:50m, grilla:10x10) [19] implementado en la función HeatMap de QGIS [20] para los puntos de movimiento de cada usuario de cada día. El algoritmo permitió identificar las rutas frecuentes recorridas por los usuarios. Adicionalmente se calculó la Ruta Óptima Teórica (ROT) mediante la herramienta de “direcciones” de Google Maps que permite incluir datos históricos de tráfico como parámetro para el cálculo [21]. Se evaluó el porcentaje de correspondencia entre la RMF y la ROT a través de un análisis de superposición entre la RMF y un *buffer* de 50 m de la ROT.



## 2.4 Validación

Se validaron tres resultados del análisis ( $POI_R$ ,  $POI_T$  y RMF) mediante una encuesta aplicada a los voluntarios (**ANEXO 2**). Se obtuvieron medidas de sensibilidad para cada uno de estos resultados (ecuación 1).

$$Sensibilidad = \frac{VP}{VP + FN} \quad \text{Ecuación 1}$$

Dónde:  $VP$  (Verdaderos Positivos) indica el número total de POIs detectados por el algoritmo que efectivamente fueron validados por los participantes, y  $FN$  (Falsos Negativos) indica el número de POIs que no fueron detectados por el algoritmo pero que efectivamente son  $POI_T$  o  $POI_R$  para los usuarios.

Además se validó la precisión espacial de los  $POI_R$  y  $POI_T$  calculando la distancia entre el punto detectado por el algoritmo y el ubicado por el usuario, en un plano vial de la ciudad, al momento de realizar la encuesta.

La validación de modos de viaje tuvo serias limitaciones debido al reducido número de usuarios que utilizó el módulo de validación incluido en la aplicación. No fue posible validar los  $POI_i$  debido a la dificultad de los voluntarios para recordar con precisión dichos sitios.

Para la validación de viajes de regreso al  $POI_R$ , se procedió a contabilizar la cantidad de regresos a este POI determinado por el algoritmo. El resultado se comparó con la cantidad de viajes de este tipo declarado por los usuarios en la encuesta.

Finalmente, no fue posible realizar una validación de las RMFs debido al amplio período entre la recolección de datos y la ejecución de las encuestas de validación (4 meses) debido a que esta información estuvo sujeta a la capacidad de recordar de los participantes, imposibilitando su comparación.

## 3 Resultados y Discusión

En la implementación piloto participaron 68 estudiantes voluntarios de la Universidad de Cuenca, quienes utilizaron la aplicación en su teléfono móvil Android para recolectar datos de movilidad durante un período de 14 días en Enero de 2016. Durante la fase de depuración se eliminaron los registros de 24 individuos por contener información insuficiente (menor a 3 días). Los datos de los 44 voluntarios restantes, consistente en un conjunto de 623619 puntos, fueron incluidos en los siguientes pasos. El análisis se enfocó solamente en el comportamiento de movilidad en días laborables, por lo que se excluyó los datos de fines de semana. El conjunto final incluyó 489144 puntos.

La encuesta de validación pudo aplicarse a 33 voluntarios, mientras que el módulo de validación de modos de transporte fue utilizado solamente por 6 usuarios (**Figura 4**).






Figura 4. Diagrama de participación

### 3.1 Detección de POIs

El algoritmo de detección basado en DBScan identificó un total de 100 POIs (**ANEXO 3**) los cuales fueron categorizados como Lugar de Residencia ( $POI_R=41$ ), Lugar de Trabajo/Estudio ( $POI_T=33$ ) y puntos intermedios ( $POI_I=26$ ) (**Figura 5**). La validación presentó una sensibilidad de detección de  $POI_R$  y  $POI_T$  del 91% y 74% respectivamente. La precisión de los  $POI_R$  fue de 160m y de los  $POI_T$  fue de 200m, para el 99.9% de los casos (**Figura 6**). La detección de viajes de regreso al  $POI_R$  presentó una sensibilidad del 86%.

Los resultados de la validación indican que el método de detección de POIs fue adecuado para detectar los lugares de residencia y aceptable para los lugares de trabajo/estudio, más aún si se considera la alta heterogeneidad de los dispositivos utilizados. Estos valores son similares a lo encontrado por Ohashi et al, (sensibilidad del 89%) [22].




Figura 5. Categorización de puntos de interés




Figura 6. Precisión de la identificación de los POIR y POIT, Frecuencia y Frecuencia Acumulada de Errores

Un resultado no planificado durante la implementación piloto fue la detección de patrones de movilidad atípicos a nivel colectivo, representados por distribuciones espaciales distintivas. Por ejemplo, el día 6 de enero se observó una concentración inusual de POI en la zona oriental del centro histórico (**Figura 7**), correspondiendo con el lugar y hora de una festividad local. Esta capacidad de detección de patrones atípicos representa una importante ventaja del método propuesto, pues permite la exploración y descubrimiento de eventos espacio-temporales que modifican los patrones de movilidad de la ciudad. Esto coincide con resultados reportados en estudios anteriores [23].

### 3.2 Matriz origen - destino

Los datos obtenidos en la Matriz OD (**ANEXO 4**) demostraron comportamientos de movilidad de los usuarios a lo largo del día y para diferentes períodos de tiempo. Cabe recalcar que estos comportamientos son particularmente gobernados por la unidad funcional 4, donde se ubica la Universidad de Cuenca, debido a que la mayoría de los participantes fueron estudiantes voluntarios universitarios por ello el POIT es el mismo para casi todos los usuarios.

Se observó, durante los 10 días analizados y para un lapso de 24 horas, (**Figura 8. D**) un total de 243 viajes intra-zonales y 995 inter-zonales. De estos 128 viajes intra-zonales y 185 inter-zonales pertenecieron al período diurno. Mientras que en el período de la tarde se encontró 78 viajes intra-zonales y 234 inter-zonales. En el período nocturno se observó 121 viajes intra-zonales y 400 inter-zonales. En conclusión se determinaron variaciones de interacción entre las unidades funcionales para los diferentes períodos de tiempo analizados. En el período diurno pudo apreciarse, comparado con los otros dos períodos, la existencia de mayor cantidad



de viajes intra-zonales (**Figura 8A: zonas**) y menor cantidad de viajes inter-zonales (**Figura 8A: líneas**); esto probablemente porque los trayectos estuvieron dirigidos hacia zonas donde se ubicaban los  $POI_T$ . Durante el período de la tarde primaron los viajes intra-zonales e inter-zonales hacia el centro de la ciudad (zonas 2) y las zonas cercanas a esta (ej.: zonas 3 y 5) (**Figura 8. B**), probablemente porque se direccionaban hacia  $POI$ s habituales de la hora del almuerzo. En el período nocturno (**Figura 8. C**) se incrementaron los viajes intra-zonales e inter-zonales hacia diversas zonas de la ciudad; esto probablemente por qué los usuarios se direccionaban hacia  $POI_R$  dispersos por toda la urbe. Se esperaría una similitud entre los viajes realizados en la mañana y los de la noche; empero la generación del periodo nocturno desde las 15h00 produjo la detección de viajes intermedios adicionales y no habituales en el periodo diurno, evitando la presencia de semejanzas entre estos periodos.






Figura 7. Identificación visual de comportamientos de movilidad atípicos (área dentro del círculo).




Figura 8. Frecuencia del total de viajes registrados entre las unidades funcionales, para diferentes períodos de tiempo.



### 3.3 Matrices de tiempo de viajes

Es importante indicar el valor agregado que se introduce mediante el uso del elemento de Matriz de tiempo de viajes (**ANEXO 5**). Puede notarse que el tiempo promedio que un usuario invierte en movilidad durante un día normal es de 37.5 minutos. Se evidenció variaciones entre los días de la semana y entre los días similares de las dos semanas analizadas. Se observó mayor cantidad de viajes, y de tiempos de viaje, durante la primera semana y para todos los días de esta (**Figura 9**). La ausencia de relación entre los días equivalentes de estas dos semanas se podría explicar porque la primera semana del año produce el regreso de las personas a la ciudad para retomar a sus actividades normales después de un feriado largo.




Figura 9. Comparación entre el número de usuarios, la cantidad y el tiempo de viajes en días equivalentes de dos semanas consecutivas del mes de enero, 2016

La matriz de tiempo de viaje produjo ventanas de viajes de los datos de movilidad de todos los usuarios (**Figura 10**), de los 10 días de las dos semanas. Se determinó que

el tiempo de inicio y fin de estas ventanas son similares para los días análogos de las dos semanas, excepto para el día viernes. Una explicación para la divergencia entre los días viernes podría radicar en que el día viernes 15 se suspendieron las actividades docentes en el campus universitario por lo que se desplazó el tiempo de inicio de viajes a las 9h00 am.




Figura 10. Viajes de cada Usuario en un periodo de 24 horas de lunes a viernes, durante dos semanas consecutivas.

La matriz de tiempo de viajes permitió además cuantificar la cantidad de tiempo invertido en los desplazamientos inter-zonales e intra-zonales. El análisis mostró que el tiempo que se invierte en realizar viajes intra-zonales no guarda la misma relación con el número total de viajes (**Figura 11**). Se evidenció que la cantidad de viajes intra-zonales bordea el 20% del total de viajes y representa solo un 5% del tiempo invertido, es decir existe un predominio de viajes inter-zonales en número y en tiempo, lo cual indica la importancia de movilización entre zonas. Es probable que exista una mejoría en la movilidad de la ciudad si se trasformara la distribución de

los equipamientos en las unidades funcionales, con el objetivo de que los usuarios minimicen los viajes inter-zonas y consecuentemente los tiempos de viaje.



Figura 11. Viajes de cada Usuario en un periodo de 24 horas, de lunes a viernes durante dos semanas consecutivas.

### 3.4 Modos de Transporte

Los datos sobre modo de transporte pudieron ser validados únicamente en seis usuarios quienes utilizaron el módulo de validación de detección de viajes en la aplicación móvil. Se determinó que en promedio dos de ellos se trasladaban en bicicleta y dos en medios de transporte motorizados, mientras que en los dos restantes la detección fue errónea. En la **Figura 12** se puede distinguir un patrón típico de desplazamiento en automóvil (velocidad: alta, acelerómetro: bajo), en Bicicleta (velocidad: baja, acelerómetro: alto) y Caminata (velocidad: baja, acelerómetro: alto). A pesar de las limitaciones presentadas, el potencial del método de detección de modalidad de viaje es prometedor.




Figura 12. Determinación de Aceleración y Velocidad para los modos de transporte, ejemplos de modos.

### 3.5 Identificación de rutas

Los mapas de calor permitieron identificar las RMFs para 33 usuarios (**ANEXO 3**). Adicionalmente se calcularon 33 ROTs para el medio de transporte más habitual de cada usuario a partir de los datos de la encuesta de validación.

La **Figura 13** muestra un mapa agregado de todas las RMFs para el estudio piloto, puede apreciarse que se marcan con claridad las vías que los usuarios escogen para aproximarse a la Universidad de Cuenca, que es como se mencionó previamente, el origen y destino de muchos viajes en consecuencia de que los usuarios fueron mayormente universitarios.

La **Figura 14** muestra un ejemplo de comparación entre la RMF y la ROT para el usuario 196964 y el usuario 198999. El análisis de correspondencia espacial indicó que el 63.6% de los usuarios mostraban una coincidencia entre el 70% y el 99% las RMFs y las ROTs. Uno de los factores que potencialmente incide en la diferencia entre RMFs y ROTs es la existencia de puntos intermedios, que en el estudio piloto representan el 20% de los POIs. Este resultado implica una diferencia importante entre los patrones reales de movilidad de las personas en comparación con aquellos obtenidos de simulaciones basadas en rutas óptimas utilizadas comúnmente en los

modelos de movilidad, ratifica la importancia de utilizar información real de movilidad derivada de datos con alta resolución espacio-temporal, que no son posibles obtener con técnicas tradicionales de encuestas OD o simulaciones.






Figura 13. Representación de RMFs dentro del área de estudio.





Usuario: 196968



Usuario: 198999

Figura 14. Comparación entre ruta óptima teórica y ruta más frecuente para dos usuarios.





## 4 Conclusión

Luego de una revisión exhaustiva de la bibliografía pertinente se pudo concluir que este es el primer estudio realizado en Ecuador sobre determinación de patrones de movilidad mediante un método de análisis de datos obtenidos por una aplicación para dispositivos móviles Android. El método planteado presenta coherencia con trabajos previos, mostrando niveles de confianza equiparables. El mayor reto es la implementación masiva del modelo, la cual alimentaría a las 4 etapas requeridas en la modelación de tránsito y transporte de ciudades, provincias e incluso a nivel país. Es probable que con el apoyo de instituciones que tienen grandes alcances con la población (ej.: la alcaldía, un ente estatal) esta situación pueda ser resuelta. De conseguir este apoyo, y por consiguiente, el empleo masivo del programa, sería posible muestrear un segmento muy alto de la población, mayor a cualquier estándar de encuestas en hogares, puesto que de acuerdo al Instituto Ecuatoriano de Estadísticas y Censos en el año 2014 el 24% de los hogares poseían un teléfono inteligente y esta cifra experimenta un crecimiento continuo si se compara con la de años previos [24].

El método propuesto además de aportar con información adecuada para ser empleada dentro del modelo de 4 etapas proporciona datos que permitirían crear zonificaciones (zonas de atracción y generación de viajes) más acordes al verdadero modelo de ciudad. Adicionalmente se corroboraron las ventajas del método propuesto de recolección de información de movilidad (aplicación móvil) sobre el tradicional (encuesta). Se observó mediante el primer método un menor tiempo de recolección, digitación y análisis de datos, menor presupuesto para su implementación, así como también la posibilidad de actualización frecuente de la información recolectada. Por su parte el método de encuesta (ej.: Plan de movilidad) mostró mayor consumo de tiempo y dinero, dificultades en el cumplimiento de una muestra representativa [1, 4], lo cual explicaría la dificultad de la implementación de actualizaciones periódicas; consecuentemente la obtención de resultados de matrices O-D para diferentes períodos de tiempos difícilmente pudieran ser obtenidos aplicando el método de encuesta, debido a la gran cantidad de información que debiera ser recolectada lo cual incrementaría ampliamente los costos [6]. Por ello la utilización de métodos menos costosos, como aplicaciones móviles, pudieran ser una opción aceptable para generar una base sólida de información para la optimización del transporte.

Ciertos estudios han planteado realizar isolineas temporales [25, 26] para el análisis de tiempos de viajes, las cuales relacionan un solo punto de origen con diversos destinos probables. Sin embargo la matriz de tiempo de viajes propuesta permitió identificar las relaciones entre todas las zonas de la ciudad y potencialmente entre todos los pares POI<sub>R</sub> y POI<sub>T</sub>. Se pudo calcular el promedio de todos los tiempos de viajes que comunican una zona con otra, mostrando todas las posibles conexiones entre las zonas y el tiempo probable para realizar dichos desplazamientos. La utilización de estas matrices de tiempo ayudarían a la cuantificación del tiempo



empleado para movilizarse ya sea una empresa de transporte, un colectivo u incluso la ciudad, lo cual puede ser fácilmente traducido a costos. La determinación de estos costos sería de gran utilidad ya que se podría identificar el verdadero gasto que se adiciona al transporte de mercancías y por ende a la economía de las ciudades, según lo planteado por el Banco Interamericano de Desarrollo. Esta entidad tiene especial interés en generar metodologías para calcular estos valores, debido a que existe una gran afluencia de transporte de mercancías por carretera que justifican esta necesidad (ej.: 60% del transporte de mercancías en América Latina) [27]. El tiempo total que invierten los individuos en transportarse puede convertirse en un indicador a ser monitoreado constantemente pudiendo así evaluar la calidad del modelo de transporte para su mejora y optimización constante.

Es necesario reconocer las limitaciones de esta investigación. Entre ellas constan: i) la determinación de periodos de viaje secundarios, ii) errores en la detección de posicionamiento del GPS (falsos positivos), iii) detección de viajes cortos como periodos de estancia, secundario a zonas límite del GPS o viajes de corta distancia dentro de la zona de estancia (falsos negativos) [28], iv) amplio período entre la recolección de datos y la ejecución de las encuestas de validación (4 meses), por lo que se consideró validar la información de movilidad con menor probabilidad de cambios como es la ubicación del POI Lugar de residencia y Lugar de Trabajo/Estudio, numero de regresos al POI Lugar de residencia y la identificación de rutas frecuente, debido a que los resultados estuvieron sujetos a la capacidad de recordar de los participantes.

Futuros estudios podrán comprobar si la precisión de este método puede mejorar al implementen las siguientes recomendaciones: i) Explorar nuevas formas de obtener los datos de ubicación de los usuarios, puesto que existen más fuentes de información (ej.: Librerías Basadas en Ubicación o LBS, Librerías Basadas en Redes Sociales o LBSN, proveedores de servicios para teléfonos inteligentes, tabletas o usuarios de servicios web, etc.); ii) Ampliar la muestra; iii) Aplicar una encuesta de validación, física o en la aplicación móvil, o un diario de viajes en un periodo corto de tiempo con el objetivo de que el usuario recuerde sus recorridos y de evitar que los datos obtenidos se vean afectados por situaciones personales o de entorno (ej.: Cambio de casa); iv) validar la identificación de puntos intermedios y producir modelos locales de matrices de impedancia ajustados a los parámetros de decisión reales aquí descritos; v) Probar distintos parámetros del DBSCAN con el fin de mejorar precisiones y evitar ciertos errores en la detección de viajes entre zonas poco distantes; vi) incluir términos de privacidad y una solicitud de autorización de empleo de estos datos, con el objetivo de cuidar el derecho a la privacidad de las personas [29, 30], ya que al utilizarse información de ubicación personal es imprescindible cumplir con la legislación al respecto.



## 5 Referencias

- [1] J. Ortúzar and L. Willusen, "Modeling Transport. 4nd," *Edition New York: John Wiley and Sons Inc*, pp. 55 - 137, 2011.
- [2] K. Martens, E. Hurvitz, and T. R. Board, "Transport modeling and justice: the case of the fourstep model," in *85th Annual Meeting of the Transportation Research Board*, 2007.
- [3] M. G. McNally and C. Rindt, "The activity-based approach," *December*, vol. 1, p. 2000, 2000.
- [4] GAD Municipal, "Plan de Movilidad y Espacios Públicos, un nuevo enfoque para la Movilidad en Cuenca," Cuenca, Ecuador 2015.
- [5] C. Renso, S. Puntoni, E. Frentzos, A. Mazzoni, B. Moelans, N. Pelekis, *et al.*, "Wireless network data sources: tracking and synthesizing trajectories," in *Mobility, Data Mining and Privacy*, ed: Springer, 2008, pp. 73-100.
- [6] F. Calabrese, G. Di Lorenzo, L. Liu, and C. Ratti, "Estimating origin-destination flows using mobile phone location data," *IEEE Pervasive Computing*, vol. 10, pp. 0036-44, 2011.
- [7] G. Draijer, N. Kalfs, and J. Perdok, "Global positioning system as data collection method for travel research," *Transportation Research Record: Journal of the Transportation Research Board*, pp. 147-153, 2000.
- [8] P. Stopher, C. FitzGerald, and J. Zhang, "Search for a global positioning system device to measure person travel," *Transportation Research Part C: Emerging Technologies*, vol. 16, pp. 350-369, 2008.
- [9] M. Bierlaire, J. Chen, and J. Newman, "Modeling route choice behavior from smartphone GPS data," *Report TRANSP-OR*, vol. 101016, p. 2010, 2010.
- [10] D. Orellana, C. Hermida, and P. Osorio, "a Multidisciplinary Analytical Framework for Studying Active Mobility Patterns," *ISPRS-International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, pp. 527-534, 2016.
- [11] Gartner. (2015). *Gartner Says Worldwide Smartphone Sales Grew 9.7 Percent in Fourth Quarter of 2015*. Available: <http://www.gartner.com/newsroom/id/3215217>
- [12] c. d. Wikipedia. *Anexo:Historial de versiones de Android*. Available: <https://es.wikipedia.org/w/index.php?title=Anexo:Historial de versiones de Android&oldid=90761322>
- [13] A. Developers, "Dashboards," *online*, *Android Developer Program*, <http://developer.android.com/about/dashboards/index.html>, 2016.
- [14] S. Pousty and K. Miller, *Getting started with OpenShift*: "O'Reilly Media, Inc.", 2014.
- [15] M. Li, J. Dai, S. Sahu, and M. Naphade, "Trip analyzer through smartphone apps," in *Proceedings of the 19th ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems*, 2011, pp. 537-540.
- [16] M. R. Berthold, N. Cebon, F. Dill, T. R. Gabriel, T. Kötter, T. Meinl, *et al.*, "KNIME-the Konstanz information miner: version 2.0 and beyond," *AcM SIGKDD explorations Newsletter*, vol. 11, pp. 26-31, 2009.
- [17] S. Hwang, T. Hanke, and C. Evans, "Automated extraction of community mobility measures from GPS stream data using temporal DBSCAN," *Lecture Notes in Computer Science*, vol. 7972, pp. 86-98, 2013.
- [18] D. Orellana and M. Wachowicz, "Exploring Patterns of Movement Suspension in Pedestrian Mobility. 行人移动停靠模式的探索性分析," *Geographical analysis*, vol. 43, pp. 241-260, 2011.
- [19] D. E. Seaman and R. A. Powell, "An evaluation of the accuracy of kernel density estimators for home range analysis," *Ecology*, vol. 77, pp. 2075-2085, 1996.



- [20] A. Pryke, S. Mostaghim, and A. Nazemi, "Heatmap visualization of population based multi objective algorithms," in *International Conference on Evolutionary Multi-Criterion Optimization*, 2007, pp. 361-375.
- [21] M. L. Yiu, Y. Lin, and K. Mouratidis, "Efficient verification of shortest path search via authenticated hints," in *Data Engineering (ICDE), 2010 IEEE 26th International Conference on*, 2010, pp. 237-248.
- [22] H. Ohashi, P. X. Nguyen, T. Akiyama, M. Yamamoto, and A. Sato, "Trip-Extraction Method Based on Characteristics of Sensors and Human-Travel Behavior for Sensor-Based Travel Survey," *Journal of Information Processing*, vol. 24, pp. 39-48, 2016.
- [23] F. Calabrese, M. Colonna, P. Lovisolo, D. Parata, and C. Ratti, "Real-time urban monitoring using cell phones: A case study in Rome," *Intelligent Transportation Systems, IEEE Transactions on*, vol. 12, pp. 141-151, 2011.
- [24] INEC, "Compendio estadístico 2014," in *Tecnología de la información y comunicación (TIC)*, ed. Quito: INEC, 2014, pp. 233 - 238.
- [25] P. Forer and H. Kivell, "Space—Time Budgets, Public Transport, and Spatial Choice,"
- [26] W. Zeng, C.-W. Fu, S. M. Arisona, A. Erath, and H. Qu, "Visualizing mobility of public transportation system," *Visualization and Computer Graphics, IEEE Transactions on*, vol. 20, pp. 1833-1842, 2014.
- [27] M. Mesquita Moreira, J. S. Blyde, C. Volpe Martincus, and D. Molina, "Muy lejos para exportar: Los costos internos de transporte y las disparidades en las exportaciones regionales en América Latina y el Caribe," 2013.
- [28] H. Ohashi, T. Akiyama, M. Yamamoto, and A. Sato, "Automatic trip-separation method using sensor data continuously collected by smartphone," in *Intelligent Transportation Systems (ITSC), 2014 IEEE 17th International Conference on*, 2014, pp. 2984-2990.
- [29] M. Wachowicz, A. Vázquez-Hoehne, D. Ballari, D. Orellana-Vintimilla, and A. Rodríguez-de-Castro, "Human Mobility Patterns: A Source of Geospatial Knowledge," *Promoted by CEPIS (Council of European Professional Informatics Societies) and published, on its behalf, by Novática, journal of the Spanish CEPIS society ATI (Asociación de Técnicos de Informática)*, p. 16, 2009.
- [30] D. Pedreschi, F. Bonchi, F. Turini, V. S. Verykios, M. Atzori, B. Malin, *et al.*, "Privacy protection: regulations and technologies, opportunities and threats," in *Mobility, Data Mining and Privacy*, ed: Springer, 2008, pp. 101-119.